

Clustering Hasil Produksi Perikanan Di Provinsi Sulawesi Selatan dengan Metode K-Means

Adiatma*

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, adiatma.rasyid@uin-alauddin.ac.id

Adnan Sauddin

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, adnan.sauddin@uin-alauddin.ac.id

Wahidah alwi

Program Studi Matematika, FST, Universitas Islam Negeri Alauddin Makassar, wahidah.alwi@uin-alauddin.ac.id

Muh. Irzan

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, muh.1rz4n@gmail.com

**Corresponding Author*

ABSTRAK, Penelitian ini bertujuan untuk mengelompokkan kabupaten/kota di Provinsi Sulawesi Selatan berdasarkan karakteristik hasil produksi perikanan menggunakan metode K-means. Penelitian menggunakan data produksi perikanan tahun 2023 yang mencakup variabel total produksi udang, bandeng, lele, nila, dan ikan mas. Metode K-means digunakan untuk mengelompokkan wilayah ke dalam tiga *cluster*: *Cluster 1* yang dominan dalam total produksi lele (Makassar), *Cluster 2* dengan dominasi total produksi udang, bandeng, nila, dan ikan mas (Bone dan Pinrang), serta *Cluster 3* yang memiliki produksi yang lebih merata dan tanpa dominasi total produksi tertentu. Hasil *clustering* ini menunjukkan adanya variasi produksi perikanan yang signifikan di tiap daerah, yang dapat menjadi dasar bagi pemerintah dalam merumuskan strategi peningkatan produksi di wilayah dengan hasil yang rendah.

Kata Kunci: Analisis *Cluster*, *K-Means*, Hasil Produksi Perikanan.

1. PENDAHULUAN

Berdasarkan data dari Badan Pusat Statistik pada tahun 2024, hasil produksi perikanan budidaya di Sulawesi Selatan meningkat 8% dari tahun 2022-2023. Hal ini bisa disebabkan oleh berbagai hal seperti ukuran area tanah, tenaga kerja, dan pakan [1]. Untuk mencapai target yang lebih baik dari tahun sebelumnya, terdapat kendala internal seperti keterbatasan tersedianya benih dan indukan yang berkualitas, serta keterbatasan tersedianya pakan yang berkualitas dengan harga terjangkau. Selain itu, terdapat juga kendala eksternal seperti tidak adanya kepastian ruang untuk usaha perikanan budidaya dan adanya perubahan iklim dan degradasi kualitas lingkungan [2]. Budidaya perikanan dilakukan untuk meningkatkan produktivitas perairan melalui berbagai kegiatan

budidaya yang dapat di kelompokkan dalam beberapa jenis seperti; jaring apung, jaring tancap, karamba, kolam air, minapadi sawah, dan tambak [3].

Data dari Satu Data Sulawesi Selatan pada tahun 2023 menunjukkan bahwa setiap wilayah kabupaten/kota memiliki hasil produksi perikanan budidaya yang berbeda. Terdapat wilayah yang memiliki hasil produksi perikanan budidaya yang lebih tinggi dari wilayah lainnya seperti Kabupaten Pinrang yang dapat memproduksi udang hingga 14.701 ton dalam setahun. Hal ini berbeda dengan Kabupaten Pare-Pare yang hanya memproduksi 17 ton dalam setahun. Ini bisa terjadi karena sejumlah faktor yang memengaruhi, seperti kepadatan populasi, jumlah rumah tangga yang terlibat dalam perikanan budidaya, luas area budidaya perikanan, dan kepadatan populasi [4].

Adapun penelitian sebelumnya yang dilakukan oleh [5] menggunakan metode *K-means* diperoleh bahwa setiap kabupaten/kota menempati cluster yang berbeda-beda sesuai dengan karakteristik datanya. Berdasarkan hasil penelitian tersebut, metode *K-means* mampu untuk mengelompokkan objek dalam jumlah besar dan mendeteksi pencilan dengan sangat cepat, sehingga mempercepat proses pengelompokan.

Berdasarkan data dari Badan Pusat Statistik yang menunjukkan bahwa pada tahun 2021 hasil produksi perikanan budidaya di wilayah Sulawesi Selatan yang mengalami peningkatan dari tahun sebelumnya menarik minat peneliti untuk melakukan penelitian

diwilayah tersebut. Penelitian akan di fokuskan pada pengindentifikasian Kabupaten/Kota di provinsi Sulawesi Selatan berdasarkan indikator hasil produksi perikanan menggunakan metode *clustering*.

Penelitian ini memiliki potensi untuk menjadi sumbangan dalam pengembangan perikanan budidaya di Sulawesi Selatan dalam upaya menyediakan pasokan ikan yang memadai, memperbaiki kesejahteraan masyarakat, serta menjaga keberlanjutan ekosistem perairan. Dalam rangka menghadapi tantangan yang kompleks di masa depan, maka dari itu penulis tertarik untuk melakukan penelitian mengenai “*Clustering* Hasil Produksi Perikanan di Provinsi Sulawesi Selatan dengan Metode *K-means*”.

2. TINJAUAN PUSTAKA

Analisis Multivariat

Menurut [6], analisis multivariat adalah suatu metode statistik yang meneliti beberapa pengukuran (variabel) pada setiap objek dalam satu atau lebih sampel secara bersamaan. Dalam hal ini, teknik analisis yang mempertimbangkan lebih dari dua variabel secara simultan dapat dianggap sebagai analisis multivariat. Data multivariat timbul ketika peneliti berupaya memahami berbagai fenomena yang melibatkan pengamatan terhadap satu atau lebih variabel. Setiap nilai hasil pengamatan dari variabel-variabel tersebut dikenal sebagai item, unit percobaan, atau eksperimen. Kita menggunakan notasi x_{ij} untuk menunjukkan nilai dari i variabel yang diamati pada j pengamatan.

x_{ij} = hasil pengukuran dari variabel ke- j pada pengamatan ke- i

Hasilnya, n pengamatan pada p variabel bisa ditampilkan sebagai berikut:

	Variabel 1	Variabel 2	..	Variabel k	...	Variabel p
Item 1	x_{11}	x_{12}	..	x_{1j}	...	x_{1p}
Item 2	x_{21}	x_{22}	..	x_{2j}	...	x_{2p}
⋮	⋮	⋮	..	⋮	...	⋮
Item i	x_{i1}	x_{i2}	..	x_{ij}	...	x_{ip}
⋮	⋮	⋮	..	⋮	...	⋮
Item n	x_{n1}	x_{n2}	..	x_{nj}	...	x_{np}

Hasil pengamatan juga dapat direpresentasikan dalam sebuah struktur data berbentuk array persegi yang disebut sebagai Matriks X, yang terdiri dari n baris dan p kolom:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2j} & \dots & x_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{ip} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nj} & \dots & x_{np} \end{bmatrix}$$

Normalisasi

Normalisasi adalah proses pengskalaan nilai atribut dari data sehingga bisa jatuh pada range tertentu [7]. Pada proses normalisasi dilakukan dengan metode *Z-score normalization*, yaitu metode normalisasi data yang digunakan untuk menskalakan nilai-nilai dalam dataset sehingga memiliki rata-rata (mean) 0 dan deviasi standar (standard deviation) 1, berikut persamaan pada metode *Z-score normalization*:

$$\text{Nilai normalisasi} = \frac{x_{ij} - \mu_j}{sd(x_j)} \quad (2.1)$$

Keterangan:

x_{ij} adalah nilai asli dari data

μ_j adalah rata-rata dari variabel

$sd(x_j)$ adalah standar deviasi dari variabel

Analisis Cluster

Analisis *cluster* adalah metode yang digunakan untuk menemukan dan mengelompokkan data dengan karakteristik yang serupa dalam satu set data. *Clustering* adalah salah satu teknik dalam data mining yang bersifat tanpa arahan (unsupervised), yang berarti metode ini diterapkan tanpa proses pelatihan atau pengawasan, serta tidak memerlukan target output. Dalam data mining, terdapat dua jenis metode *clustering* yang digunakan untuk pengelompokan data, yaitu *hierarchical clustering* dan *non-hierarchical clustering* [8].

Hierarchical clustering adalah metode pengelompokan data yang diawali dengan mengelompokkan dua atau lebih objek yang memiliki kesamaan paling tinggi. Proses ini kemudian berlanjut dengan mengelompokkan

objek-objek lain berdasarkan tingkat kesamaan berikutnya [8]. Proses ini terus berlanjut hingga terbentuk sebuah struktur pohon dengan hierarki yang jelas antar objek, mulai dari yang paling mirip hingga yang paling tidak mirip. Pada akhirnya, semua objek akan tergabung dalam satu *cluster*.

Sebaliknya, metode non-hierarchical *clustering* dimulai dengan menentukan jumlah *cluster* yang diinginkan terlebih dahulu (misalnya, dua *cluster*, tiga *cluster*, dll.). Setelah jumlah *cluster* ditetapkan, proses pengelompokan dilakukan tanpa mengikuti hierarki tertentu. Metode ini dikenal sebagai *k-means clustering* [8]. Analisis *cluster* memisahkan kumpulan data ke dalam satu atau lebih *cluster* tertentu. Sebuah *cluster* yang baik adalah *cluster* di mana anggotanya memiliki karakteristik yang sangat mirip, sementara *cluster* yang lain memiliki karakteristik yang sangat berbeda satu sama lain.

K-Means

K-means adalah metode *clustering* non-hierarki yang mengelompokkan data ke dalam satu atau lebih *cluster* atau kelompok [8]. Data dengan karakteristik yang berbeda ditempatkan dalam *cluster* yang berbeda, sehingga terdapat sedikit variasi data dalam setiap kelompok. Algoritma *K-means* termasuk dalam Partitioning Method, yaitu metode yang membangun berbagai partisi dan mengevaluasi partisi tersebut berdasarkan beberapa kriteria.

Kelebihan dari metode *K-means* adalah kemampuannya untuk mengelompokkan objek dalam jumlah besar dan mendeteksi pencilan dengan sangat cepat, sehingga mempercepat proses pengelompokan. Namun, kelemahan *K-means* adalah sensitif terhadap pemilihan titik pusat awal yang dilakukan secara acak dan hasil pengelompokannya tidak selalu konsisten atau dapat berubah-ubah [9].

Berikut adalah rumus untuk mengukur jarak dalam algoritma *K-means*:

$$d_{(x,y)} = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (2.2)$$

Keterangan:

$d_{(x,y)}$ = Euclidean Distance

x_1 = koordinat object ke-1

y_1 = koordinat *centroid* ke-1

x_2 = koordinat object ke-2

y_2 = koordinat *centroid* ke-2

x_n = koordinat object ke-n

y_n = koordinat *centroid* ke-n

Jarak terdekat antara *centroid* dan dokumen menentukan ke dalam *cluster* mana dokumen tersebut akan masuk. Sebagai contoh, jika dokumen A memiliki jarak terpendek ke *centroid* 1 dibandingkan dengan *centroid* lainnya, maka dokumen A akan masuk ke dalam kelompok 1. Posisi *centroid* baru untuk setiap *centroid* (C_i) kemudian dihitung kembali dengan mengambil rata-rata dokumen yang masuk ke dalam *cluster* awal (G_i). Proses iterasi ini akan terus dilakukan sampai posisi kelompok tidak lagi berubah [10].

Selain digunakan untuk menghitung *centroid* baru, hasil dari *centroid* akhir dapat digunakan untuk mengetahui karakteristik *cluster* yang terbentuk. Berikut adalah rumus untuk menentukan *centroid* baru:

$$C(k) = \frac{1}{N_k} (x_{1k} + x_{2k} + \dots + x_{nk}) \quad (2.3)$$

Keterangan:

x_{1k} = nilai data record ke-1 (k)

x_{2k} = nilai data record ke-2 (k)

x_{nk} = nilai data record ke-n (k)

N_k = jumlah data record (k)

3. METODOLOGI

Langkah-langkah yang diambil dalam penelitian ini adalah sebagai berikut:

1. Mendefinisikan setiap variabel
2. Melakukan analisis deskriptif
3. Melakukan normalisasi data
4. Melakukan uji multikolinearitas
5. Melakukan metode *cluster K-means* sebagai berikut:
 - a. Menentukan jumlah *cluster*
 - b. Memilih pusat *cluster* awal
 - c. Melakukan perhitungan jarak dari tiap objek ke pusat *cluster*
 - d. Menempatkan setiap objek ke dalam *cluster* yang memiliki jarak terdekat dengan pusat *cluster* tersebut

- Adiatma, Adnan Sauddin, Wahidah Alwi, Muh.Irzan

- Menghitung ulang pusat dari *cluster* yang telah terbentuk
- Lakukan pengulangan langkah-langkah dari langkah b hingga tidak ada lagi perpindahan objek antara *cluster*

- Mendeskripsikan karakteristik *cluster*.
- Menarik kesimpulan.

4. HASIL

Statistik Deskriptif

Berikut gambaran umum dari data yang diolah dengan menggunakan analisis deskriptif. Adapun statistik deskriptif dari masing-masing variabel pada data yang diolah dapat di lihat pada Tabel 4.1 berikut:

Tabel 4.1 Statistik Deskriptif

Statistik	X1	X2	X3	X4	X5
Min	0	0	0.5	2.1	22.6
Max	15872	84280	1204.7	3098.8	3296
Rata-rata	2803.97	7218.7	136.38	490	229.6
1st Qu.	3379.82	9514.9	113.78	755.3	229.6
3rd Qu.	17.48	12.53	25	40.3	229.6
Standar Deviasi	4578.83	17261.6	250.64	734.15	229.6

Normalisasi Data

Berdasarkan tabel statistik deskriptif sebelumnya, variabel-variabel tersebut memiliki rentang nilai yang sangat berbeda. Oleh karena itu, data perlu dinormalisasikan terlebih dahulu untuk memastikan data memiliki rentang nilai yang sama menggunakan persamaan Z-Score Normalization.

Hasil normalisasi dengan menggunakan persamaan Z-Score Normalization dapat dilihat pada Tabel 4.2.

Tabel 4.2 Hasil Normalisasi Data


Kabupaten atau Kota	X1	X2	X3	X4	X5
KEPULAUAN SELAYAR	-0.6003	-0.4161	-0.5421	-0.6639	-0.6944
BULUKUMBA	0.2069	-0.3279	-0.0198	-0.4954	-0.6098
BANTAENG	-0.6044	-0.4128	-0.4871	-0.6191	-0.6879
JENEPONTO	-0.2088	-0.2493	-0.5094	-0.6584	-0.6839
TAKALAR	-0.3860	-0.3344	-0.4444	-0.6355	-0.6939
GOWA	-0.5820	-0.4092	0.3356	-0.1269	-0.3417
SINJAI	-0.5925	-0.4148	-0.4444	-0.6103	-0.6571
MAROS	0.1250	0.1107	0.3851	0.5462	-0.5327
PANGKEP	-0.0946	0.2001	-0.4978	2.0609	-0.6530
BARRU	0.3491	-0.3814	-0.1411	-0.5292	-0.6858
BONE	2.8540	4.4643	1.1675	0.7797	1.1226
SOPPENG	-0.6124	-0.4182	-0.1208	-0.5179	-0.4224
WAJO	1.8143	0.4031	-0.1136	0.3592	0.4838
SIDRAP	-0.6124	-0.4182	-0.4324	0.5058	-0.1451
PINRANG	2.5983	0.3686	-0.4332	3.5535	3.2805
ENREKANG	-0.6124	-0.4182	-0.5317	0.1170	-0.0405

LUWU	0.0738	0.2176	-0.2776	-0.6049	0.4185
TANA TORAJA	-0.6124	-0.4182	-0.4009	-0.5229	0.4352
LUWU UTARA	-0.2353	0.0641	-0.1707	0.3679	1.3667
LUWU TIMUR	0.1282	0.4302	0.5874	-0.2882	0.0613
TORAJA UTARA	-0.6124	-0.4182	-0.3805	-0.4418	1.7103
MAKASSAR	-0.6086	-0.4172	4.2624	-0.2728	-0.6944
PAREPARE	-0.6086	-0.4182	-0.3961	-0.6646	-0.6944
PALOPO	-0.5668	-0.3864	-0.3945	-0.6385	-0.6419

Berdasarkan Tabel 4.2 diperoleh hasil normalisasi data untuk kelima variabel. Berdasarkan data yang telah di normalisasi, dapat di ketahui bahwa data telah berada di rentang yang sama dengan nilai yang berbeda. Hasil normalisasi yang bernilai negatif menunjukkan bahwa data tersebut berada dibawah nilai rata-rata dan nilai positif menunjukkan bahwa data berada di atas nilai rata-rata.

Menentukan jumlah *cluster*

Penentuan jumlah *cluster* yang optimal dilakukan dengan menggunakan metode *elbow* dengan melihat titik di mana penurunan mulai melambat secara signifikan seperti yang terlihat pada gambar 4.1.



Gambar 4.1 Plot Elbow

Berdasarkan gambar 4.6, terlihat penurunan mulai melambat secara signifikan dari titik 2 ke titik 3. Setelah titik 3, penurunan titik menjadi lebih lambat dan kurva mulai mendatar. Berdasarkan plot *elbow* yang ditampilkan, jumlah *cluster* yang akan digunakan yaitu 3.

Menentukan *Centroid* Awal

Setelah jumlah optimal cluster diperoleh, selanjutnya, menentukan *centroid* awalnya yaitu C1 (*centroid cluster*), C2 (*centroid cluster*), dan C3 (*centroid cluster*). Nilai dari *centroid* ini diperoleh secara acak dari data yang ada pada data yang tersedia. Namun, untuk memastikan ketiga titik *centroid* tersebut bervariasi sehingga dipilih tiga *centroid* yang memiliki total produksi yang dominan untuk satu variabel, dominan pada dua variabel dan tidak memiliki hasil dominan

sama sekali, sehingga di peroleh ketiga *cluster* awal yaitu:

$$C1 = \{-0.6086, -0.4172, 4.2624, -0.2728, -0.6944\}$$

$$C2 = \{2.5983, 0.3686, -0.4332, 3.5535, 3.2805\}$$

$$C3 = \{0.0738, 0.2176, -0.2776, -0.6049, 0.4185\}$$

Menentukan Jarak Tiap Kabupaten/Kota untuk Setiap *Centroid*

Untuk menghitung jarak tiap kabupaten/kota untuk setiap *centroid* dapat dilakukan dengan menggunakan persamaan *Euclidean Distance*.

Kepulauan Selayar

$$d_{(x1,C1)} = \sqrt{((-0.60) - (-0.61))^2 + \dots + ((-0.6944) - (-0.6944))^2} = 4.8204$$

$$d_{(x1,C2)} = \sqrt{((-0.60) - 2.60)^2 + \dots + ((-0.6944) - 3.2805)^2} = 6.6667$$

$$d_{(x1,C3)} = \sqrt{((-0.60) - (-0.07))^2 + \dots + ((-0.6944) - 0.4185)^2} = 1.4724$$

Untuk hasil perhitungan jarak selanjutnya dapat dilihat pada Tabel 4.3.

Tabel 4.3 Hasil Perhitungan *Euclidean Distance*

Kabupaten/Kota	Cluster 1	Cluster 2	Cluster 3
KEPULAUAN SELAYAR	4.8204	6.6667	1.4724
BULUKUMBA	4.3666	6.1565	1.2046
BANTAENG	4.7621	6.6354	1.4579
JENEPONTO	4.8070	6.4594	1.2529
TAKALAR	4.7267	6.5379	1.3350
GOWA	3.9454	6.1625	1.4161
SINJAI	4.7190	6.6058	1.4243
MAROS	4.0678	5.5170	1.6380
PANGKEP	5.3622	4.9984	2.8865
BARRU	4.5139	6.1730	1.2955
BONE	7.0574	5.6350	5.5014
SOPPENG	4.3985	6.4275	1.2706
WAJO	5.2422	4.3293	2.0061
SIDRAP	4.7905	5.6525	1.5654
PINRANG	7.9618	0.0000	5.6483
ENREKANG	4.8542	5.8117	1.2929
LUWU	4.7780	5.6483	0.0000
TANA TORAJA	4.8047	5.9700	0.9473
LUWU UTARA	4.9681	4.6906	1.4057
LUWU TIMUR	3.9164	5.6805	1.0120
TORAJA UTARA	5.2314	5.4184	1.6065
MAKASSAR	0.0000	7.9618	4.7780
PAREPARE	4.6749	6.6705	1.4581
PALOPO	4.6718	6.5991	1.3837

Setelah menghitung jarak setiap data menggunakan persamaan *euclidean distance*, selanjutnya menempatkan setiap kabupaten/kota ke dalam *cluster* yang memiliki jarak terdekat dengan *centroid*. Untuk menentukan apakah iterasi selanjutnya akan dilakukan, nilai *centroid* baru akan dihitung. Jika nilai *centroid* baru berbeda dengan *centroid* sebelumnya, maka

iterasi selanjutnya akan dilakukan. Proses ini akan berlanjut hingga nilai *centroid* baru sama dengan *centroid* sebelumnya atau tidak ada perpindahan *cluster*.

Menghitung Nilai *Centroid* Baru dengan Keanggotaan *Cluster* yang Terbentuk

Untuk mendapatkan nilai *centroid* baru dapat dilakukan dengan menghitung rata-rata dari semua kabupaten/kota dalam setiap *cluster* untuk setiap variabel atau atribut data. Berdasarkan hasil perhitungan setiap *cluster*, diperoleh nilai masing-masing *centroid*-nya yaitu $C1 = \{-0.6086, -0.4172, 4.2624, -0.2728, -0.6944\}$, $C2 = \{2.7262, 2.4165, 0.3672, 2.1666, 2.2015\}$, dan $C3 = \{-0.2307, -0.2103, -0.2379, -0.1934, -0.1766\}$. Dari hasil *centroid* baru yang diperoleh, hasilnya berbeda dengan *centroid* sebelumnya sehingga iterasi selanjutnya perlu dilakukan hingga hasilnya tidak ada perpindahan *cluster* atau telah konvergen. Untuk hasil perhitungan jarak pada iterasi ke-2 dapat dilihat pada Tabel 4.4.

Tabel 4.4 Hasil Perhitungan *Euclidean Distance* Iterasi Ke-2

Kabupaten/Kota	Cluster 1	Cluster 2	Cluster 3
KEPULAUAN SELAYAR	4.8204	6.0261	0.8724
BULUKUMBA	4.3666	5.3868	0.7292
BANTAENG	4.7621	5.9946	0.8279
JENEPONTO	4.8070	5.7267	0.7412
TAKALAR	4.7267	5.8435	0.7384
GOWA	3.9454	5.5369	0.7236
SINJAI	4.7190	5.9642	0.7875
MAROS	4.0678	4.7101	1.1364
PANGKEP	5.3622	4.6665	2.3586
BARRU	4.5139	5.4167	0.8642
BONE	7.0574	2.8175	5.9981
SOPPENG	4.3985	5.7888	0.6069
WAJO	5.2422	3.3665	2.3054
SIDRAP	4.7905	5.2996	0.8465
PINRANG	7.9618	2.8175	5.8623
ENREKANG	4.8542	5.4053	0.6246
LUWU	4.7780	4.8110	0.8949
TANA TORAJA	4.8047	5.4886	0.8357
LUWU UTARA	4.9681	4.3041	1.6664
LUWU TIMUR	3.9164	4.6206	1.1339
TORAJA UTARA	5.2314	5.1755	1.9574
MAKASSAR	0.0000	6.9757	4.5512
PAREPARE	4.6749	6.0117	0.8374
PALOPO	4.6718	5.9359	0.7637


Pada hasil perhitungan iterasi ke-2 dapat diketahui bahwa tidak ada perpindahan *cluster*, sehingga iterasi selanjutnya tidak perlu dilakukan karena hasilnya akan sama atau hasilnya telah konvergen.

Pembentukan Hasil *Cluster* Menggunakan *K-means*

Berdasarkan Tabel 4.4 hasil *clustering k-means* diperoleh tiga *cluster* dengan jumlah anggota untuk setiap *cluster*-nya yaitu, *cluster* 1 adalah 1 Kabupaten/Kota, *cluster* 2 adalah 2 Kabupaten, dan *cluster* 3 adalah 21 Kabupaten. Berdasarkan tabel 4.4, diperoleh hasil *cluster* beserta anggotanya dapat di lihat pada tabel 4.5 dan gambar 4.2.

Tabel 4.5 Hasil *Cluster* Beserta Anggotanya

<i>Cluster</i>	Anggota (Kabupaten/Kota)
<i>Cluster</i> 1	Makassar
<i>Cluster</i> 2	Bone dan Pinrang.
<i>Cluster</i> 3	Kepulauan Selayar, Bulukumba, Bantaeng, Jeneponto, Takalar, Gowa, Sinjai, Maros, Pangkep, Barru, Soppeng, Wajo, Sidrap, Enrekang, Luwu, Tana Toraja, Luwu Utara, Luwu Timur, Toraja Utara, Parepare, dan Palopo



Gambar 4.2 Visualisasi *Cluster*

Berdasarkan hasil karakteristik *cluster* dan hasil visualisasi *cluster*-nya, dapat diketahui bahwa setiap *cluster* memiliki karakteristik yang cukup berbeda.

Karakteristik *Cluster*

Untuk mengetahui karakteristik setiap *cluster* dapat dilakukan dengan membandingkan rata-rata setiap variabel di antara tiga *cluster*. Analisis ini digunakan untuk memahami karakteristik dari setiap *cluster* berdasarkan variabel yang dianalisis yaitu X1, X2, X3, X4, dan X5. Berikut nilai rata-rata variabel pada setiap *cluster* yang dapat di lihat pada Tabel 4.6:

Tabel 4.6 Rata-rata setiap variabel untuk masing-masing *cluster*

<i>Cluster</i>	X1	X2	X3	X4	X5
<i>Cluster</i> 1	-0.6086	-0.4172	4.2624	-0.2728	-0.6944
<i>Cluster</i> 2	2.7262	2.4165	0.3672	2.1666	2.2015
<i>Cluster</i> 3	-0.2307	-0.2103	-0.2379	-0.1934	-0.1766

Berdasarkan tabel 4.5 dan tabel 4.6 dapat di ketahui bahwa karakteristik untuk setiap *cluster* seperti yang ditampilkan pada tabel 4.7

Tabel 4.7 Karakteristik Setiap *Cluster*

<i>Cluster</i>	Karakteristik
<i>Cluster</i> 1	Kelompok ini merupakan <i>cluster</i> yang dominan memproduksi variabel X3 (total produksi lele)
<i>Cluster</i> 2	Kelompok ini merupakan <i>cluster</i> yang dominan memproduksi variabel X1 (total produksi udang), X2 (total produksi bandeng), X4 (total produksi nila), dan X5 (total produksi ikan mas)
<i>Cluster</i> 3	Kelompok ini merupakan <i>cluster</i> yang tidak memiliki variabel yang dominan

Berdasarkan Tabel 4.7 dapat diketahui bahwa pada *cluster* 1, variabel yang paling dominan yaitu X3 (total produksi Lele) dan pada *cluster* 2, variabel yang paling dominan yaitu X1 (total produksi udang), X2 (total produksi Bandeng), X4 (total produksi Nila), dan X5 (total produksi Ikan Mas). Sedangkan *cluster* 3 tidak memiliki variabel yang paling dominan.

5. PEMBAHASAN

Berdasarkan hasil analisis diperoleh tiga cluster diantaranya yaitu cluster 1 beranggotakan Makassar dan cluster 2 terdiri dari Bone dan Pinrang. Sedangkan cluster 3 anggotanya mencakup seluruh kabupaten dan kota di Sulawesi Selatan, kecuali anggota cluster 1 dan cluster 2. Cluster 3 merupakan cluster dengan total produksi yang seragam untuk semua variabel, tanpa ada dominasi total produksi tertentu.

Pada cluster 1 yang anggotanya hanya terdiri dari Kota Makassar, memiliki karakteristik dominan pada variabel total produksi lele dengan total produksi 1204.7 Ton.

Meskipun cluster ini menonjol dalam produksi lele, hasil produksi pada variabel lainnya tergolong rendah, terutama pada variabel total produksi ikan mas yang tidak memiliki produksi sama sekali. Namun, hal tersebut dapat di atasi dengan mengambil pasokan pada anggota cluster dengan total produksi yang dominan untuk variabel total produksi ikan mas.

Cluster 2 yang terdiri dari Kabupaten Bone dan Kabupaten Pinrang, menunjukkan karakteristik dominan pada 4 variabel di antaranya yaitu variabel total produksi udang dengan total produksi 9997.5 Ton, total produksi bandeng dengan total produksi 84280 Ton, total produksi nila dengan total produksi 3098.8 Ton, dan total produksi ikan mas dengan total produksi 2302.6 Ton. Meskipun pada variabel total produksi lele mereka tidak dominan, Kabupaten Bone menempati urutan kedua dengan total produksi 429 Ton setelah Makassar dengan total produksi 1446.1 Ton, sedangkan produksi lele di Kabupaten Pinrang sangat rendah dengan total produksi 30.9 Ton.

Walaupun variabel total produksi lele di Kabupaten Bone dan Kabupaten Pinrang tidak mendominasi, pada variabel lainnya keduanya selalu menonjol. Misalnya, pada Kabupaten Bone menunjukkan produksi paling dominan pada variabel total produksi udang dengan total produksi 9997.5 Ton dan variabel total produksi bandeng dengan total produksi 84280 Ton. Sedangkan pada Kabupaten Pinrang mendominasi pada variabel total produksi nila dengan total produksi 3098.8 Ton dan variabel total produksi ikan mas dengan total produksi 2302.6 Ton. Berdasarkan karakteristik ini, cluster 2 dapat dikategorikan sebagai kelompok dengan hasil produksi yang tinggi.

Cluster 3 yang anggotanya terdiri dari Kepulauan Selayar, Bulukumba, Bantaeng, Jeneponto, Takalar, Gowa, Sinjai, Maros, Pangkep, Barru, Soppeng, Wajo, Sidrap, Enrekang, Luwu, Tana Toraja, Luwu Utara, Luwu Timur, Toraja Utara, Parepare, dan Palopo, menunjukkan karakteristik total produksi yang seragam di semua variabel, tanpa ada dominasi total produksi tertentu. Untuk variabel total produksi udang, Kabupaten Wajo menunjukkan hasil produksi yang cukup tinggi

pada variabel total produksi udang dengan total produksi 11111.5 Ton. Namun, produksi pada variabel lainnya tergolong rendah. Kabupaten Pangkep juga memiliki total produksi yang cukup tinggi pada variabel total produksi nila dengan total produksi 753.7 Ton, sementara produksi pada variabel lainnya sangat rendah.

6. KESIMPULAN

Berdasarkan hasil analisis dapat disimpulkan bahwa pengelompokan hasil produksi perikanan dengan metode analisis *k-means* cluster menggunakan 3 cluster diperoleh hasil yaitu cluster 1 terdiri dari 1 kabupaten atau kota yaitu Makassar. Cluster 2 terdiri dari 2 kabupaten yakni Bone dan Pinrang dan cluster 3 terdiri dari 21 kabupaten atau kota yaitu Kepulauan Selayar, Bulukumba, Bantaeng, Jeneponto, Takalar, Gowa, Sinjai, Maros, Pangkep, Barru, Soppeng, Wajo, Sidrap, Enrekang, Luwu, Tana Toraja, Luwu Utara, Luwu Timur, Toraja Utara, Parepare, dan Palopo.

Masing-masing cluster memiliki karakteristik yaitu cluster 1 (Produksi Sedang) merupakan kelompok dengan produksi paling dominan untuk variabel Total Produksi Lele. Cluster 2 (Produksi Tinggi) merupakan kelompok dengan produksi paling dominan untuk 4 variabel yaitu Total Produksi Udang, Total Produksi Bandeng, Total Produksi Nila, dan Total Produksi Ikan Mas. Sedangkan cluster 3 (Produksi Rendah) tidak memiliki produksi yang dominan.

7. DAFTAR PUSTAKA

- [1] A. Fahrudin, "Analisis Pendapatan dan Faktor-Faktor yang Mempengaruhi Produksi Usaha Budidaya Tambak Ikan," *Effic. Indones. J. Dev. Econ.*, vol. 1, no. 1, pp. 77–85, 2018, doi: 10.15294/efficient.v1i1.27223.
- [2] Y. P. S. Tholibah Muhtahidah, Dian Novita Sari, Dwi Utami Putri, Meillisa Carlen Mainassy, Inem Ode, Muh. Amri Yusuf, Ria Retno, Laily Fitriani Mulyani, Zaenal Abidin, *Budidaya Perikanan*.

- TOHAR MEDIA, 2023.
- [3] Badan Pusat Statistik, “Badan Pusat Statistik.” [Online]. Available: <https://www.bps.go.id/>
- [4] S. A. Arsandi, A. Afriyanto, and V. Kumalasari, “Analisis faktor-faktor yang Mempengaruhi Pertumbuhan Industri Perikanan di Indonesia,” *Nekt. J. Perikan. dan Ilmu Kelaut.*, vol. 2, no. 1, pp. 13–26, 2022, doi: 10.47767/nekton.v2i1.312.
- [5] A. Firlansyah, A. A. N. Risal, F. Adiba, and A. B. Kaswar, “Clustering Produksi Perikanan Budidaya Laut Berdasarkan Provinsi Menggunakan Algoritma K-Means,” *J. Embed. Syst. Secur. Intell. Syst.*, vol. 2, no. 1, p. 55, 2021, doi: 10.26858/jessi.v2i1.20378.
- [6] W. R. Dillon and M. Goldstein, *Multivariate Analysis: Methods and Applications*. New York (N.Y.): Wiley, 1984.
- [7] E. Irfiani and S. S. Rani., “Algoritma K-Means Clustering untuk Menentukan Nilai Gizi Balita,” *JUSTIN (Jurnal Sist. dan Teknol. Informasi)*, vol. 6(4), pp. 165–172., 2018.
- [8] R. Hablum, A. Khairan, and R. Rosihan, “Clustering Hasil Tangkap Ikan Di Pelabuhan Perikanan Nusantara (Ppn) Ternate Menggunakan Algoritma K-Means,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 2, no. 1, pp. 26–33, 2019, doi: 10.33387/jiko.v2i1.1053.
- [9] I. Nasution, A. P. Windarto, and M. Fauzan, “Penerapan Algoritma K-Means Dalam Pengelompokan Data Penduduk Miskin Menurut Provinsi,” *Build. Informatics, Technol. Sci.*, vol. 2, no. 2, pp. 76–83, 2020, doi: 10.47065/bits.v2i2.492.
- [10] D. N. Nango, “Penerapan Algoritma K-Means Untuk Clustering Data Anggaran Pendapatan Belanja Daerah Di Kabupaten XYZ,” *Skripsi*, 2012.